

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE DENNÍCH AKTIVIT

HUMAN ACTIVITY CLASSIFICATION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jakub Müller

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Radovan Smíšek

BRNO 2021

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Jakub Müller

ID: 211581

Ročník: 3

Akademický rok: 2020/21

NÁZEV TÉMATU:

Klasifikace denních aktivit

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou automatické klasifikace aktivit pomocí akcelerometru a/nebo EKG. 2) Provedte rešerši veřejně dostupných databází vhodných pro testování algoritmů klasifikujících aktivity. 3) Navrhněte a realizujte algoritmus pro automatickou klasifikaci vybraných aktivit. Algoritmus otestujte na veřejně dostupné databázi. 4) Optimalizujte navržený algoritmus. 5) Nasnímejte signály EKG a ACC a podrobně zaznamenejte vykonávané aktivity. Otestujte vytvořený algoritmus na těchto signálech. 6) Porovnejte dosaženou úspěšnost s ostatními autory.

DOPORUČENÁ LITERATURA:

[1] YANG F. a ZHANG L., Real-Time Human Activity Classification by Accelerometer Embedded Wearable Devices, 2017 4th International Conference on Systems and Informatics (ICSAI), Hangzhou, 2017, pp. 469-473, doi: 10.1109/ICSAI.2017.8248338.

[2] JAIN A. a KANHANGAD V., Human Activity Classification in Smartphones Using Accelerometer and Gyroscope Sensors, IEEE Sensors Journal, vol. 18, no. 3, pp. 1169-1177, 1 Feb.1, 2018, doi: 10.1109/JSEN.2017.2782492.

Termín zadání: 8.2.2021

Termín odevzdání: 28.5.2021

Vedoucí práce: Ing. Radovan Smíšek

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Bakalářská práce se zabývá klasifikací denních aktivit z akcelerometrických dat. V teoretické části práce jsou obecně shrnuty denní aktivity a přínosy jejich monitorování. Dále navazuje kapitola o akcelerometrech a principech jejich fungování. V závěru teoretické části jsou popsány základy umělých neuronových sítí a SVM. Praktická část spočívala ve výběru veřejně dostupné databáze s akcelerometrickými daty denní aktivity a v naměření akcelerometrických vlastních dat. Dále v návrhu a optimalizaci algoritmu ke zpracování dat, provedení klasifikace využitím zvolených modelů a vyhodnocení výsledků úspěšnosti.

KLÍČOVÁ SLOVA

akcelerometr, denní aktivita, databáze, FAROS, příznaky, klasifikace, neuronová síť, support vector machine

ABSTRACT

This bachelor's thesis describes daily activity classification using accelerometric data. The first theoretical part summarizes the basics about daily activity and benefits that we get from monitoring it. In the next part of theory the principles of accelerometer inner workings are described. The last part of theory is dedicated to explaining the basics of neural networks and SVM. The aim of the practical part was to find a suitable dataset from a publically shared database, containing daily activity accelerometric data and also to collect our own data. Then performing classification using our own algorithm, optimizing it and finally evaluating the results.

KEYWORDS

accelerometer, daily activity, database, FAROS, features, classification, neural network, support vector machine

MÜLLER, Jakub. *Klasifikace denních aktivit*. Brno, 2021, 47 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Radovan Smíšek

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Klasifikace denních aktivit“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu bakalářské práce panu Ing.Radovanu Smíškovi, za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	8
1 Sledování denní aktivity	9
1.1 Denní aktivita	9
1.2 Systémy na principu vizuálního pozorování	9
1.3 Akcelerometry	10
1.3.1 MEMS	11
1.3.2 Zařízení FAROS	13
1.3.3 Technické údaje zařízení FAROS 180	15
2 Problematika veřejně přístupných databází	16
2.1 Popis databáze UCI HAR	16
2.1.1 Formát dat UCI HAR	17
2.2 Popis databáze WARD	20
2.2.1 Formát dat WARD	22
3 Klasifikace aktivit	25
3.1 Support vector machine	25
3.2 Klasifikace pomocí neuronových sítí	26
3.2.1 Preceptron	27
3.3 Výběr příznaků	28
3.3.1 Analýza hlavních komponent	28
4 Měření vlastních dat a popis vybraných příznaků	29
4.1 Měření dat pomocí zařízení FAROS 180	29
4.2 Příprava dat	31
4.3 Vybrané příznaky	32
4.4 Neuronová síť	34
5 Optimalizace algoritmu	35
6 Výsledky a diskuze	36
6.1 Porovnání výsledků neuronové sítě s SVM	39
Závěr	43
Literatura	45
Seznam symbolů, veličin a zkratk	47

Seznam obrázků

1.1	Příklad vykreslení dat v softwaru Qualisys	10
1.2	Model jednoduchého akcelerometru, převzato a přeloženo z[4]	11
1.3	Rozložení os akcelerometru v mobilním telefonu, převzato z [6]	12
1.4	Schéma MEMS akcelerometru	13
1.5	Zařízení Bittium FAROS 180[7]	14
1.6	Umístění zařízení FAROS na subjektu, který vykonával aktivity	14
2.1	Očekávané hodnoty zrychlení u senzoru UCI HAR na vodorovné ploše	17
2.2	Vykreslení úseku měření UCI HAR 1/2	18
2.3	Vykreslení úseku měření UCI HAR 2/2	19
2.4	Jeden z pěti senzorů databáze WARD, převzato z [2]	21
2.5	Rozmístění akcelerometrů na pacientovi z databáze WARD	22
2.6	Vykreslení úseku dat WARD 1/2	23
2.7	Vykreslení úseku dat WARD 2/2	24
3.1	Schéma metody SVM	26
3.2	Schéma samotného neuronu, převzato z[11]	27
4.1	Vykreslení úseku dat ze zařízení FAROS 1/2	29
4.2	Vykreslení úseku ze zařízení FAROS 2/2	30
4.3	Ukázka funkce mediánového filtru na datech z WARD	32
4.4	Schéma vlastní neuronové sítě	34
5.1	Příklad matice záměn z testování datsetu WARD	35
6.1	Matice záměn z testování vlastního datsetu	36
6.2	Matice záměn z testování datsetu WARD	37
6.3	Matice záměn z testování datsetu UCI HAR	38
6.4	Matice záměn z testování vlastních dat pomocí SVM	40
6.5	Matice záměn z testování WARD pomocí SVM	40
6.6	Matice záměn z testování UCI HAR pomocí SVM	41
6.7	Bodový diagram pro znázornění nízké separability	42
6.8	Výsledná úspěšnost klasifikace, převzato z:[12]	42

Úvod

Tělesná aktivita je nedílnou součástí zdravého životního stylu a její sledování má velký přínos jak pro běžného člověka, tak pro medicínu a další vědecké obory. Dodržovat pravidelný denní režim spojený s dostatkem pohybu může být často problém, ale díky miniaturizaci senzorů a jejich implementaci do běžně používaných zařízení jako jsou chytré telefony, náramky nebo hodinky, si dnes můžeme dovolit sami monitorovat své činnosti a mít pravidelný přehled o svých denních aktivitách a své tělesné kondici.

Způsobů monitoringu je více, ale nejčastěji se volí použití akcelerometrů, které měří zrychlení v závislosti na pohybu zařízení, ve kterém jsou zabudovány. Data mohou být ukládána přímo v interní paměti zařízení nebo posílána skrze komunikační modul na externí uložště, odkud lze data načíst pro další zpracování a klasifikaci.

Při klasifikaci lze postupovat různými metodami. Stále častěji jsou používány algoritmy strojového učení, do kterých řadíme i neuronové sítě a *Support Vector Machine neboli algoritmus podpůrných vektorů* (SVM), jimiž se budeme v této práci věnovat. Právě z důvodu širšího používání algoritmů strojového učení, je nutné mít dostatek dat k jejich naučení. K tomu jsou velmi nápomocny online databáze, které jsou vytvářeny za účelem poskytnutí dat pro vývoj, učení a další výzkumy v této oblasti.

V první části práce se budeme zabývat základními principy snímání dat denní aktivity a technologiemi, které se při nich uplatňují. Dále se zaměříme na problematiku veřejně přístupných databází, vytvořených za účely testování a vývoje klasifikačních algoritmů denních aktivit. V navazující části budou zkráceně vysvětleny principy fungování neuronových sítí a SVM spolu s vysvětlením extrakce dat z naměřených signálů.

Důležitým krokem před klasifikací dat, je provedení jejich analýzy a zpracování, spolu s výběrem příznaků, na které je zaměřen začátek praktické části práce. Zde jsou ve stručnosti shrnuty základní postupy práce s výběrem příznaků spolu se souvisejícími metodami. V další kapitole praktické části je popsán proces optimalizace sítě spolu s dosaženými výsledky úspěšnosti klasifikace.

Poslední kapitola obsahuje veškeré dosažené výsledky klasifikace, jak pro neuronovou síť, tak pro SVM a porovnání mezi nimi.

1 Sledování denní aktivity

1.1 Denní aktivita

Téma které je individuální pro každého z nás a může se lišit v mnoha ohledech – naše denní aktivita. Variabilitu denního programu můžeme připsat různým parametrům jako je pohlaví, věk, místo bydliště či pracovní nasazení pozorovaného subjektu.

V současnosti je téma klasifikace a sledování denní aktivity velmi aktuálním především díky pokrokům ve vývoji "smart" zařízení a nositelných technologií jako jsou chytré náramky, hodinky, telefony, nebo boty či chytré zubní kartáčky a podobná zařízení. Uživatelé zmíněných zařízení mohou pravidelně sledovat svoji aktivitu a zároveň plnit různé nastavené cíle, jako je ujít 10000 kroků denně a sdílet své úspěchy s ostatními.

Například systém chytrých zařízení od značky Xiaomi funguje na principu párování zařízení s chytrým telefonem skrze aplikaci, ve které má každý uživatel vytvořený osobní profil, na kterém může procházet historii svých záznamů a spravovat svá data. Zároveň má možnost vyhledávat ostatní uživatele, například své přátele a zobrazit si jejich denní činnosti, aktivitu během dne nebo kvalitu jejich spánku.


Uplatnění záznamů denní aktivity najdeme taktéž ve zdravotnictví, kde mohou být nápomocné k monitorování chronických onemocnění nebo při fyzioterapeutických výkonech, kdy pacienti po úrazech končetin nebo po mozkových příhodách trpí omezenou schopností pohybu[1]. Jejich monitorování během rehabilitačních procedur pomáhá při zkoušení cvičebních metod, aplikacích různých léčiv a zvolení budoucího terapeutického postupu.

Mezi další uplatnění podobných systémů můžeme zařadit detekci pádu u starších osob, které často žijí samy nebo nad nimi není pravidelný dohled[2]. V případě, že k pádu dojde, zařízení vyhodnotí jeho vážnost a jestliže je vybaveno systémem *Global Positioning System* (GPS), zaznamená aktuální polohu a může ji přímo odeslat na *Integrovaný záchranný systém* (IZS) s výzvou o pomoc. Některá zařízení již toto umí automaticky, například pokud se dotyčný nehýbe a zvýšit pravděpodobnost přežití postiženého[3].

1.2 Systémy na principu vizuálního pozorování

Pohybové aktivity lze zaznamenávat i skrze kamerová zařízení, která poskytují velmi rozsáhlé a přesné informace celkového pohybu pozorovaného subjektu. Zástupcem z této kategorie je i systém značky *Qualisys*, který funguje na principu infračervených kamer v kombinaci s konvečními optickými kamerami. Na pozorovaný subjekt jsou umístěny markery (identifikační body), které jsou v tomto případě pasivní, což


znamená, že infračervené záření pouze odráží a nejsou jeho zdrojem. Infračervené kamery ozáří subjekt s markery od nichž se infračervené záření odráží a je zpětně detekováno samotnou kamerou. Data jsou odesílána do počítače, kde dojde ke zpracování dat a s pomocí programu přímo od výrobce, k jejich vykreslení (Obr. 1.1). Při exportu bývají data uložena ve formátu 3D matice a lze s nimi dále pracovat i v jiných programech. Tento princip má také své nevýhody, kdy může docházet k znehodnocení dat špatným nasvícením scény nebo nevhodným rozmístěním kamer. Další nevýhodou může být velikost prostoru potřebného k rozestavení jednotlivých kamer, který zároveň umožní odstínění okolního světla a v neposlední řadě taktéž cena takových systémů.[1].



Obr. 1.1: Příklad vykreslení dat v softwaru Qualisys

1.3 Akcelerometry


Akcelerometry jsou zařízení, která nám umožňují snímat hodnotu statického a dynamického zrychlení v reálném čase. Základní princip jejich fungování si můžeme popsat na jednoduchém modelu (Obr. 1.2), tvořeném vnějším obalem (dutý válec), uvnitř něhož se nachází pohyblivá hmota (kulička) zavěšená na pružině. Při pohybu s modelem dojde k rozkmitání hmoty uvnitř válce, což způsobí změnu délky pružiny. Pokud jsme schopni tuto změnu délky změřit a vhodně převést, můžeme určit okamžité tíhové zrychlení v jednom směru. Pokud zkombinujeme tři taková zařízení jsme schopni určit celkovou orientaci tělesa v prostoru[4].



Obr. 1.2: Model jednoduchého akcelerometru, převzato a přeloženo z[4]

1.3.1 MEMS

V dnešní době se nejčastěji setkáme s akcelerometry typu *Micro Electro Mechanical Systems* (MEMS), které jsou schopny zaznamenávat velikosti změn zrychlení až ve 3 osách x , y , z (Obr. 1.3). Svého uplatnění nachází zejména v chytrých přenosných zařízeních (chytré telefony, tablety, hodinky, náramky, apod) ke snímání orientace zařízení při automatickém otáčení obrazu, stabilizaci obrazu při nahrávání videa nebo k vyhodnocování denních aktivit uživatele (pokročilejší modely i v kombinaci s EKG). Dále v navigačních systémech (letecké inženýrství), čidlech otřesů ve stavbách a zařízeních vyžadujících monitorování jejich stavu, či v kardiostimulátorech k detekci pohybové aktivity nositele[5].




Obr. 1.3: Rozložení os akcelerometru v mobilním telefonu, převzato z [6]

MEMS využívají moderních metod výroby polovodičových součástek, což umožňuje vměstnat celé zařízení do jednoho malého čipu, ve kterém bývá i více senzorů najednou, jako akcelerometr, gyroskop či barometr, pak hovoříme o *Inertia Measurement Unit* (IMU). Princip fungování MEMS spočívá ve změnách elektrické kapacity uvnitř senzoru. Základní jednotkou elektrické kapacity je Coulomb (C). Pohyblivá hmota ukotvena na pružném zachycení mění svou pozici v závislosti na silách vyvolaných pohybem se senzorem, její výběžky zasahují mezi pevné elektrody a při pohybu mezi nimi dochází ke změně vzdáleností elektrod a výběžků, čímž se mění elektrická kapacita (Obr. 1.4).

Senzor zaznamenává data ve formátu zrychlení v jednotkách g . Hodnota tíhového zrychlení na Zemi, neboli jedno g , je přibližně $9,80665 \text{ m/s}^{-2}$. V jistých případech mohou být výstupní hodnoty zaznamenávány přímo jako jednotky elektrické kapacity C či jiné, kdy si je musíme, nejčastěji podle předpisu uvedeného v dokumentaci součástky přepočítat. Naměřené zrychlení můžeme popsat dvěma způsoby jako statické a dynamické. Statickým rozumíme takové zrychlení kdy je akcelerometr v relativním klidu, čili zaznamenává zejména tíhové zrychlení (projeví se vždy v určité ose, dle pozice senzoru). Dynamické zrychlení zaznamenáváme při pohybu zařízení, kdy na něj působí další síly vyvolané pohybem.

Technologie MEMS nám dovoluje měřit data mnohem pohodlněji a efektivněji díky její miniaturizaci a integraci do našich telefonů, které jsou dnes nedílnou součástí našich životů. Ve spojení s komunikačními technologiemi jako Bluetooth a Wi-

Fi nebo spolu s gyroskopem, či EKG v chytrých hodinkách, tvoří velmi atraktivní balíček, se kterým mohou dále pracovat vývojáři, zaměřující se právě na aplikace, které se týkají denních aktivit[4][5].




Obr. 1.4: Schéma MEMS akcelerometru

1.3.2 Zařízení FAROS

K nasnímáním vlastních dat bylo v této práci použito zařízení Bittium FAROS 180 (Obr. 1.5). Jedná se o jednoduché mobilní zařízení schopné měřit akcelerometrická data, pomocí tříosého akcelerometru, spolu s elektrokardiografickým záznamem střední aktivity měřeného subjektu. Zařízení disponuje vlastní interní pamětí a naměřená data se ukládají přímo do ní ve formátu *.EDF*. Propojením skrze USB kabel nebo bluetooth lze data jednoduše přepírovat do uložisti s počítače. Skrze jednoduchý software dodávaný výrobcem, lze nastavit parametr vzorkovací frekvence akcelerometru, pro měření vlastních dat byla nastavena na 100 *Hz*. Zařízení bylo na subjektu uchyceno pomocí gelové elektrody, dle Obr. 1.6.



Obr. 1.5: Zařízení Bittium FAROS 180[7]



Obr. 1.6: Umístění zařízení FAROS na subjektu, který vykonával aktivity

1.3.3 Technické údaje zařízení FAROS 180

Technické údaje zařízení FAROS 180 jsou:

- výrobce: Bittium Finsko,
- stupeň krytí: IP67 (voděodolný),
- tříosý akcelerometr,
- nastavitelná vzorkovací frekvence akcelerometru 25/100 Hz,
- nastavitelný rozsah akcelerometru 2/4/16 g,
- jednosvodové EKG,
- nastavitelná vzorkovací frekvence EKG 125/250/500/1000 Hz,
- interní uložení: 1GB,
- dobíjecí baterie Li-Ion,
- hmotnost: 18g,
- konektivita: USB, bluetooth,
- formát dat: EDF.


2 Problematika veřejně přístupných databází

Základním prostředkem nezbytným k samotnému vývoji a dalšímu zdokonalování algoritmu jsou data a přístup k nim. V dnešní době máme, díky internetu, přístup k velkému množství různých databází, které obsahují data zaměřená na problematiku ze všech možných oborů. Veřejně přístupné jsou pak takové databáze do kterých se dostane kdokoli kdo má přístup k internetu a může tak získat jejich obsah a využít ho ke svým potřebám. Nesmíme však zapomenout uvést autory pokud databázi použijeme do své práce, kterou budeme následně publikovat.

2.1 Popis databáze UCI HAR

Databáze University of California, Irvine Human Activity Recognition (*University of California, Irvine Human Activity Recognition* (UCI HAR)) vznikla za účelem vytvoření volně dostupného datasetu pro trénování, testování a vývoj algoritmů zabývajících se rozpoznáním pohybových aktivit z akcelerometrických dat. V této práci slouží UCI HAR jako zdroj trénovacích dat pro jednotlivé modely. Data byla naměřena na 30 pacientech, jejichž věk se pohybuje v rozmezí 19-48 let. Jako měřicí zařízení byl použit chytrý telefon Samsung Galaxy S II s triaxiálním akcelerometrem a gyroskopem se vzorkovací frekvencí 50 Hz. V rámci pre-processingu provedeného autory, prošly signály filtrací k odstranění šumu a následně vzorkováním metodou plovoucího okna s pevnou délkou 128 vzorků na okno a 50% překryvem, což vzhledem k vzorkovací frekvenci odpovídá 2,56 s. Naměřená data byla dále autory filtrována k oddělení gravitační složky zrychlení použitím filtru typu dolní propust s mezní frekvencí 0,3 Hz.[8].

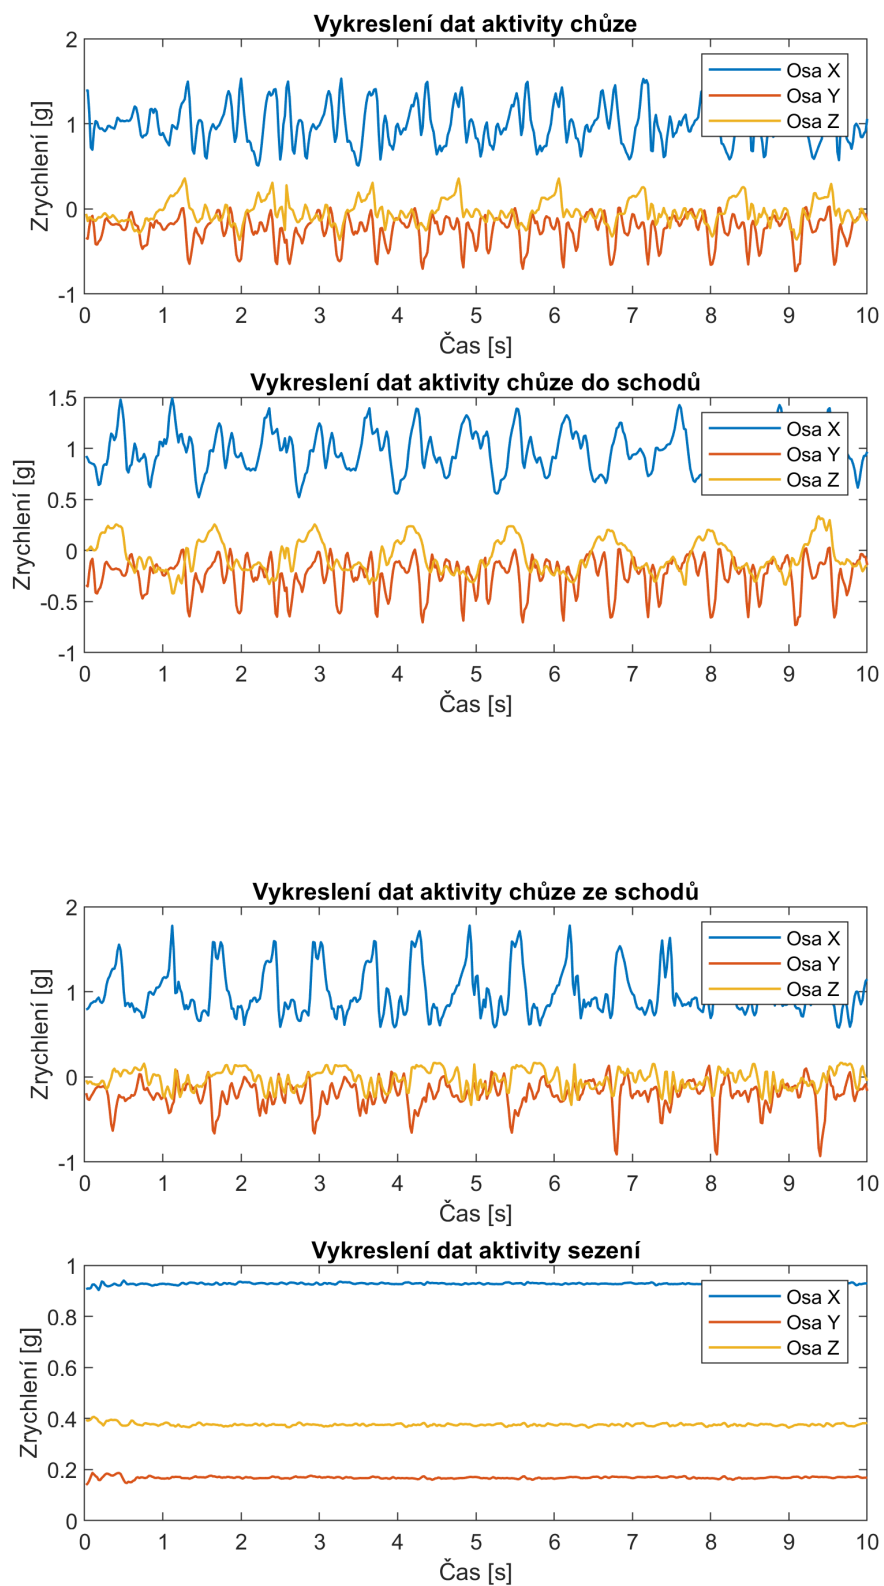
Každý z pacientů vykonával pod dohledem, v kontrolovaném prostředí laboratoře šest aktivit, mezi které patří chůze, chůze do schodů, ze schodů, sezení, stání a ležení na zádech. Telefon byl při měření umístěn uvnitř ledvinky, v poloze nad pasem osoby provádějící aktivity (Obr. 2.1).




Obr. 2.1: Očekávané hodnoty zrychlení u senzoru UCI HAR na vodorovné ploše

2.1.1 Formát dat UCI HAR

Soubory databáze zahrnují dvě složky rozdělující data na trénovací a testovací set, ve kterých se nachází data uložená ve třech souborech, dle X , Y , Z os akcelerometru. V rámci souborů databáze je vytvořená také matice příznaků o 561 sloupcích (jeden sloupec pro každý příznak) mezi které patří průměr hodnot všech tří os, směrodatné odchylky, maxima, minima. Celý seznam je vypsán v textovém souboru, který je přiložen k datům. Dále jsou přiloženy soubory obsahující indexy jednotlivých měřených aktivit subjektů, aby si je mohl koncový uživatel databáze v datech najít.



Obr. 2.2: Vykreslení úseku měření UCI HAR 1/2



Obr. 2.3: Vykreslení úseku měření UCI HAR 2/2

Z vykreslených dat (Obr. 2.2 a 2.3) můžeme vidět rozdíly a podobnosti mezi jednotlivými aktivitami. Pro chůzi lze obecně říct, že u ní můžeme pozorovat jistou periodicitu. U chůze ze schodů jsou pak výkyvy hodnot ve svislé ose větší než při chůzi do schodů. Pro ostatní tři aktivity, které jsou spíše stacionární, jsou rozdíly znát zejména v rozložení zrychlení do jednotlivých os. Senzor uvnitř zařízení má polohu senzoru, tak jak je v ledvince umístěn, kladnou částí osy X směrem k hlavě osoby (popsáno v Tab. 2.1).

Osy	Svislá poloha	Svislá poloha o 180°	Horizontální poloha	Horizontální poloha o 180°	Pravý bok	Levý bok
X	0g	0g	0g	0g	-1g	+1g
Y	+1g	-1g	0g	0g	0g	0g
Z	0g	0g	+1g	-1g	0g	0g


Tab. 2.1: Očekávané hodnoty zrychlení u telefonu z UCI HAR na vodorovné ploše

2.2 Popis databáze WARD

Spolu s projektem distribuovaného rozpoznávání lidských aktivit pomocí sítě nositelných senzorů vznikla databáze *Wearable Action Recognition Database* (WARD)[10]. Cílem projektu byl návrh distribuované sítě individuálních akcelerometrických senzorů, jenž budou komunikovat jako celek se vzdáleným serverem. Senzor detekuje a rozpozná určitou aktivitu či akci a začne posílat data do společně sdílené databáze[2]. Jestliže nositel provádí činnost, která není na seznamu požadovaných aktivit ke klasifikaci, senzor data automaticky vyřadí. Samotná databáze byla vytvořena za účelem ověření přesnosti současných a budoucích klasifikačních algoritmů [2].


Aktivitu 20 pozorovaných subjektů s poměrně širokým věkovým rozsahem 19 až 75 let byly zaznamenány pomocí 5 senzorů rozmístěných na vhodných místech, na těle každého subjektu (Obr. 2.5). Z obrázku můžeme vidět, že pozice senzorů byly zvoleny na zápěstích obou paží, okolo kotníků a v pase, což napomáhá k získání přesnějších dat a následně ulehčí rozpoznávání jednotlivých činností se zaměřením na dolní polovinu těla. V rámci klasifikace zahrnuje databáze 13 různých aktivit mezi které patří: sed, stání a leh v klidu, chůze vpřed, dokola vlevo, vpravo, otáčení vlevo, vpravo, chůze po schodech nahoru a dolů, lehký běh vpřed, skákání na místě a tlačení chodítka nebo vozičku. Počet měřených parametrů je poměrně rozsáhlý a může nalézt různých uplatnění. V rámci této práce budou z databáze WARD použita data pouze ze senzoru číslo 3 (viz Obr. 2.5) umístěném na pase subjektu a vybrány aktivity totožné s těmi z databáze UCI HAR, tedy chůze, leh, sed, stání, chůze ze schodů a do schodů.

Senzory byly navrženy a zkonstruovány samotnými autory (Obr. 2.4). Jejich návrh jim pomohl docílit požadovaných funkcí. Hardware tvoří jeden triaxiální akcelerometr a biaxiální gyroskop, jež jsou napájeny na společné desce Tmote Sky, která zahrnuje vlastní operační systém a komunikační moduly. Oproti klasickým senzorovým sítím, které nasnímají data a posílají je ke zpracování, navrhli autoři WARD metodu distribuovaného rozpoznávání. Dle jejich postupu bude každý senzor sloužit jako uzel, který se aktivuje pouze v případě detekce požadovaných aktivit (jak již bylo zmíněno výše). Rozhodování probíhá na lokální úrovni a nezatěžuje síť přenosem dat, která nejsou požadována. Tím je dosaženo i nižší spotřeby energie jednotlivých senzorů a umožňuje jim delší výdrž. Data ze všech uzlů jsou s frekvencí 30Hz odesílána na společný server, který pracuje jako globální klasifikátor a má za úkol dále optimalizovat celkový proces. Pokud by došlo k selhání či naměření špatných výsledků na některém z uzlů, globální klasifikátor může síť upravit a adaptovat například vyřazením chybných dat, či celého senzoru. I přesto se v datech vyskytují chybné vzorky měření, které jsou podle autorů způsobeny chybou v komunikaci se serverem nebo selháním baterie senzoru[2].



Obr. 2.4: Jeden z pěti senzorů databáze WARD, převzato z [2]


Sít je jako celek založena na platformě DexterNet. Jedná se o open-source software který aplikuje tří vrstvou architekturu s možností řízení různých experimentálních i komerčně dostupných senzorových platforem. První vrstvu, jež pracuje na lokální úrovni, můžeme nazvat senzorovou. Druhá vrstva, kterou autoři nazývají personální, je na úrovni komunikace a zpracování dat z jednoho pozorovaného subjektu. Třetí, globální vrstva, zabezpečuje komunikaci vrstvy personální s hlavním serverem kde dochází k ukládání dat[2].




Obr. 2.5: Rozmístění akcelerometrů na pacientovi z databáze WARD


2.2.1 Formát dat WARD

Data jsou rozdělena dle jednotlivých subjektů do příslušných složek. Každá z nich obsahuje soubory s 13 naměřenými aktivitami jejichž měření bylo provedeno na pět různých pokusů pro zvýšení celkového obsahu. Soubory jsou uloženy ve formátu ".mat" a po jejich načtení do programového prostředí Matlab se zobrazí jako proměnná typu "struct" obsahující údaje o každém souboru a samotná data v podobě buňkového pole obsahující matice s hodnotami akcelerometru spolu s gyroskopem.



Obr. 2.6: Vykreslení úseku dat WARD 1/2





Obr. 2.7: Vykreslení úseku dat WARD 2/2

Při srovnání vykreslených úseků z dat obou databází jsou si oba datasey velmi podobné. Rozdíl datasetu WARD oproti datům z UCI HAR lze vidět v jiném rozložení os použitého akcelerometru. Pokud se zaměříme na aktivitu stání v klidu z datasetu WARD vidíme naměřenou hodnotu okolo jednoho g na ose Y , oproti datasetu UCI HAR kde byl akcelerometr nasměrován kladnou částí osy X směrem nahoru (popsáno v Tab. 2.2).

Osy	Svislá poloha	Svislá poloha o 180°	Horizontální poloha	Horizontální poloha o 180°	Pravý bok	Levý bok
X	0g	0g	0g	0g	+1g	-1g
Y	+1g	-1g	0g	0g	0g	0g
Z	0g	0g	+1g	-1g	0g	0g

Tab. 2.2: Očekávané hodnoty zrychlení u senzoru WARD na vodorovné ploše


3 Klasifikace aktivit

Klasifikací rozumíme zařazení vstupních dat do určitých definovaných kategorií, které potřebujeme z dat vyhodnotit. K provedení klasifikace používáme algoritmus neboli také model jež nám zpracuje vstupní data na námi požadovaný výstup. V současnosti se stále více přihlíží k algoritmům strojového učení pro jejich výhody v provádění shlukování, regrese, či klasifikace. K vyhodnocování z dat aktivity bývá v praxi v oblibě více metod strojového učení lišících se v náročnosti na výpočet, požadavcích na předzpracování dat, flexibilitě úpravy algoritmu při optimalizaci a mnoha dalších parametrech. V praxi můžeme takový případ v rozhodování se mezi metodami vztáhnout na zařízení, které nedisponuje příliš výkonným hardware, například z důvodu šetření baterie. Proto bývá vhodnější zvolit metodu výpočetně méně náročnou, avšak musíme stále brát ohled na přijatelnou přesnost[2].

Regrese jakožto metoda matematické statistiky umožňuje odhadnout hodnotu hledané veličiny na základě znalostí jiných veličin. Princip spočívá ve zkoumání vztahů mezi proměnnými, například fyzická aktivita bude ve vyšším věku (s největší pravděpodobností) nižší než u subjektu z mladší věkové skupiny. Klasifikace řeší zařazení objektů do stanovených tříd.

3.1 Support vector machine

SVM je dalším příkladem algoritmu strojového učení používaný ke klasifikaci nebo regresi dat. Základní myšlenkou SVM, je dělení dat do kategorií pomocí dělicí přímky nebo nadroviny. Ačkoliv to může znít jednoduše v praxi je tomu naopak, zvláště v případech komplexnějších dat, kde jsou rozdíly mezi jednotlivými prvky méně zřetelné. Jako příklad si můžeme představit jednoduchý případ, lineárně separabilních dat, znázorněný níže (Obr. 3.1). Naším úkolem je nalézt ideální dělicí přímku, neboli nadrovinu, která nám oddělí data na 2 kategorie. K nalezení optimální vzdálenosti od dělicí přímky, tak abychom dosáhli maximálního rozpětí (okraje klasifikátoru), používáme body z jednotlivých kategorií, nazývané podpůrné vektory (support vector). Aby měla dělicí nadrovina maximální rozpětí, musí splňovat kritérium maximální vzdálenosti od obou kategorií dat. V případech složitěji separabilních dat, se algoritmus stále snaží najít lineární hranice převedením dat do vyšších dimenzí[9].



Obr. 3.1: Schéma metody SVM

3.2 Klasifikace pomocí neuronových sítí


Pokroky v oblasti umělé inteligence jsou za poslední léta značné a to platí i pro neuronové sítě, které nacházejí stále větších uplatnění. Prvopočátek vývoje neuronových sítí můžeme počítat od roku 1943, kdy Warren McCulloch a Walter Pitts vytvořili první matematický popis neuronu. Dále v roce 1949 navázal na vývoj Donald Hebb, návrhem způsobu učení neuronu pomocí Hebbova pravidla. Svou teorii a koncept učení popsal v knize *The Organization of Behavior*. První neuronová síť s názvem *The Perceptron* vznikla v roce 1962 zásluhou Franka Rosenblatta, kterému se podařilo propojit základní neurony. Od konce šedesátých let byl vývoj neuronových sítí pozastaven. K pokračování došlo až na počátku let osmdesátých, kdy na něj navázal například John Hopfield, podle kterého je pojmenována Hopfieldova síť, nejznámější z kategorie asociativní paměti. Vývoj a aplikace neuronových sítí od svého počátku ve čtyřicátých letech významně pokročily[11].

Použití neuronových sítí je velmi široké, díky schopnostem učení, kdy dochází k přizpůsobování struktury a parametrů sítě. Hlavní uplatnění mají v případech, které jsou složité na řešení standardními algoritmy, jako jsou klasifikační nebo regresní úlohy. Aby se mohla síť zdokonalovat, probíhá její učení v epochách (iteracích), kdy potřebuje vyhodnocovat chyby a dle nich upravovat váhy na jednotlivých neuronech.

Šíření chyb může probíhat dle dvou topologií. Při rekurentním šíření se zavádí zpětná vazba, která síti slouží k přivádění chyby z výstupu zpět na vstup. Pokud zvolíme dopřednou topologii sítě, chyba bude postupovat ve směru od vstupu k výstupu, postupně přes všechny neurony. Postupy učení sítě rozlišujeme na učení s učitelem, kdy síti předkládáme vzory, kterých se snaží dosáhnout. Naopak v případě učení bez učitele dáme síti pouze počet různých kategorií, které se ve vstupních datech vyskytují a síť samotná se snaží vyhovět zadanému kritériu ve smyslu počtu kategorií a napodobit strukturu konkrétních dat. Aby síť uměla rozlišit chyby a najít optimální řešení, potřebujeme vhodně vyjádřit kvalitu všech možných řešení, k čemuž nám slouží kritériální funkce. Analýzou jejího průběhu jsme pak schopni určit zda se optimálnímu řešení blížíme, nebo se od něj naopak vzdalujeme. Z hodnoty kritériální funkce dále počítí tzv. korekční člen, který k přepočtu vah neuronů. Učením se síť přizpůsobuje a tím napodobuje trénovací dataset, s čímž souvisí schopnost predikce. Můžeme říci, že neuronovým sítím do jisté míry vyhovují chyby, díky nim se lépe optimalizují na daný dataset, neboli upravují váhy na jednotlivých neuronech, čímž zvyšují úspěšnost klasifikace.[11].

3.2.1 Perceptron

Samostatný neuron nazýváme jednoduchým perceptronem, který představuje nej-jednodušší variantu dopředné neuronové sítě. Ve své podstatě se jedná o binární klasifikátor.



Obr. 3.2: Schéma samotného neuronu, převzato z[11]

Neuron (Obr. 3.3) můžeme popsat následující rovnicí (3.1) a její odvozenou variantou[11].

$$x = f \left[\sum_{i=1}^N w_i x_i - \vartheta \right] = f \left[\sum_{i=0}^N w_i x_i \right], \text{ pro } x_0 = 1, w_0 = -\vartheta \quad (3.1)$$

Vstupuje do něj N vstupů (x), které jsou jednotlivě vynásobeny příslušnými vahami (w) a sečteny do sumy, která je přivedena na funkci, též nazývanou aktivační funkcí neuronu[11]. Spojením většího počtu perceptronů vznikají více vrstvé neuronové sítě.

3.3 Výběr příznaků

Pojmem příznak rozumíme reprezentaci typických vlastností nějakého objektu zkoumání, v rámci této práce tak budeme chápat nasnímané signály. Metody výběru příznaků lze zjednodušeně rozdělit na extrakci a selekci. Při extrakci provádíme transformaci příznakového prostoru (x) na základě optimálního zobrazení (Z), neboli transformace funkce 3.2. Selekcce je pak jednoduchý výběr z určitého počtu příznaků, například z příznakového vektoru.

$$y = Z(x) \quad (3.2)$$

Dalším důležitým krokem je zvolení optimálního počtu příznaků, pokud budeme disponovat malým počtem došlo by k nedostačujícímu popsání našeho signálu a v dalších krocích analýzy také neefektivnímu učení sítě. V opačném případě by příliš velký počet znamenal zvýšenou výpočetní náročnost, případný overfitting modelu a redundantní, korelované příznaky. Abychom zhonotili kvalitu příznaků či jejich hodnotu jakou přispívají k celku vybraných, existují určité metody příznakové analýzy.

3.3.1 Analýza hlavních komponent


Metoda *Principle Component Analysis* neboli *analýza hlavních komponent* (PCA) slouží napříč různými obory k analýze redundance dat, neboli jejich vzájemné závislosti. V případech kdy máme na výběr z větší datové množiny a potřebujeme zjistit, která data budou mít větší výpovědní hodnotu. Základní myšlenka PCA ve vztahu k příznakové analýze spočívá v hledání jiných než korelovaných příznaků, které popisují naše data jinými způsoby avšak stále zachovávají podstatné informace přispívající efektivnímu učení modelu. Více příznaků popisujících stejnou informaci může má za následek pomalé modelu, vyšší komplexitu nebo maskování vztahů mezi příznaky.

4 Měření vlastních dat a popis vybraných příznaků


4.1 Měření dat pomocí zařízení FAROS 180

Jak již bylo zmíněno v první kapitole, k měření vlastních dat bylo použito zařízení FAROS 180 s tříosým akcelerometrem a vzorkovací frekvencí nastavenou na 100 Hz. Aktivita byly u každého z pěti subjektů, vykonávány v kontrolovaném prostředí, se stejnou posloupností. Výběr aktivit odpovídá těm, jenž byly obsaženy v databázích UCI HAR a WARD. Pořadí aktivit během měření bylo následující:

- chůze po rovné ploše,
- chůze do schodů,
- ze schodů,
- stání,
- sed,
- leh.



Obr. 4.1: Vykreslení úseku dat ze zařízení FAROS 1/2



Obr. 4.2: Vykreslení úseku ze zařízení FAROS 2/2


Každá z aktivit byla vykonávána přibližně dvě minuty. Na jednotlivých grafech s vykreslenými daty (Obr. 4.1 a 4.2) lze opět pozorovat různé rozložení tíhového zrychlení do os akcelerometru. Při porovnání s předchozími daty, jsou si nejvíce podobná s těmi z databáze UCI HAR. Oproti datům z WARD je zde opět jiné rozložení os x , y a z (popsáno v Tab. 4.1), kterého si lze jednoduše všimnout u aktivit ležení na zádech a stání. Schody jsou mezi patry přerušeny rovnými podestý, tudíž se v datech těchto aktivit vyskytuje i chůze po rovném povrchu. Což sice může mít negativní vliv při následné klasifikaci, ale data více odpovídají reálné situaci.

Osy	Svislá poloha	Svislá poloha o 180°	Horizontální poloha	Horizontální poloha o 180°	Pravý bok	Levý bok
X	+1g	-1g	0g	0g	0g	0g
Y	0g	0g	0g	0g	-1g	+1g
Z	0g	0g	-1g	+1g	0g	0g

Tab. 4.1: Očekávané hodnoty zrychlení u senzoru FAROS na vodorovné ploše

4.2 Příprava dat

V prvním kroku byla data obou databází načtena a přepracována do formátu matice se kterou bylo následně jednodušší pracovat při výpočtu příznaků. Výsledná matice má šest řádků (dle šesti aktivit), počet sloupců odpovídající vzorkům signálu a tři dimenze podle os x , y a z . U data setu z WARD byl na celý data set aplikován mediánový filtr k vyhlazení a odstranění nežádoucích kmitů (znázorněno na Obr. 4.3). U vlastních naměřených dat byl použit stejný postup. Filtrace u nich provedena nebyla, protože její aplikování vedlo spíše k znehodnocení dat, zejména u jednotlivých druhů chůze, které se od sebe liší pouze hodnotami maximálních amplitud ve svislé ose. U data setu z WARD byla provedena detekce chybných vzorků měření (v Matlabu jako Inf), na které autoři upozorňují v popisu databáze.



Obr. 4.3: Ukázka funkce mediánového filtru na datech z WARD

4.3 Vybrané příznaky

Příznaky byly z každé osy zvlášť počítány pomocí plovoucího okna s pevně nastavenou délkou, která byla pro každý data set nastavena dle délky dat (doba měření) a jejich vzorkovací frekvence. Nedostatečně dlouhé okno by nemuselo obsahovat dostatek vzorků pro vypočtení některých příznaků. V opačném případě by příliš dlouhé okno znamenalo menší počet vzorků příznaků a menší objem dat ke klasifikaci. Pro data set z UCI HAR tomu odpovídá délka okna 128 vzorků při vzorkovací frekvenci 50 Hz (délka v čase 2,56s). V databázi WARD je vzorkovací frekvence 30 Hz se zvolenou délkou okna 150 vzorků (délka v čase 5s). Pro výpočet příznaků z vlastních dat byla zvolena délka okna 300 vzorků při vzorkovací frekvenci 100 Hz (délka v čase 3s). Jako základní příznaky byly vybrány základní popisné statistické veličiny jako aritmetický průměr, maxima, minima, rozdíl maxima a minima, STD, RMS, SMA, MAD (popsány v rovnicích níže). Aritmetický průměr pomůže lépe odlišit stacionární aktivity, které se liší, pouze rozložením téměř konstantního tíhového zrychlení do jednotlivých os. K odlišení aktivních pohybů od stacionárních by měly pomoci příznaky reprezentující maximální dosažené zrychlení jako maximum, minimum, SMA, apod. Aplikováním rychlé Fourierovy transformace FFT byly získány

údaje hlavní frekvence a jejího výskytu v okně signálu, které by měly spolu s autokorelací os lépe rozlišit tři druhy chůze, jenž se od sebe liší zejména v maximální dosažené hodnotě zrychlení.

Celkem bylo z každého data setu vypočteno 11 příznaků, z nichž je 10 pro každou osu (x,y,z) zvlášť (SMA se počítá ze všech tří os dohromady). Na výpočet příznaků byla v programovém prostředí Matlab vytvořena samostatná funkce jejíž vstupy tvoří vzorkovací frekvence signálu a okna z jednotlivých os. Výsledná příznaková matice je tedy tvořena 31 řádky a sloupci dle počtu oken, který se liší v závislosti na datasetu. Celkový rozsah dat použitých pro výpočet příznaků a následnou klasifikaci příznakové matice, byl dlouhý 42 minut u vlastního datasetu, 125 minut u datasetu WARD a přes 171 minut pro dataset UCI HAR.

$$\text{Maximum : } \max(s) \quad (4.1)$$

$$\text{Minimum : } \min(s) \quad (4.2)$$

$$\text{Rozdíl maxima a minima : } \max(s) - \min(s) \quad (4.3)$$

$$\text{Aritmetický průměr : } \bar{s} = \frac{1}{n} \sum_{i=1}^n s_i \quad (4.4)$$

$$\text{Směrodatná odchylka : } \sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (s_i - \bar{s})^2} \quad (4.5)$$

$$\text{Efektivní hodnota (RMS) : } s_{RMS} = \sqrt{\frac{s_1^2 + s_2^2 + \dots + s_n^2}{n}} \quad (4.6)$$

$$\text{Signal Magnitude Area (SMA) : } s_{SMA} = \sum_{i=1}^n (|x_i| + |y_i| + |z_i|) \quad (4.7)$$

$$\text{Mediánová absolutní odchylka (MAD) : } \text{median} |s_i - \text{median}(s)| \quad (4.8)$$


$$\text{Autokorelace : } s_1(\tau) = \frac{1}{n} \sum_{i=0}^n s_1(i)x(i - \tau); s_1(\tau) = s_1(-\tau) \quad (4.9)$$

$$\text{Výskyt hlavní frekvence: z FFT (Rychlá Fourierova transformace) signálu} \quad (4.10)$$

$$\text{Hlavní frekvence signálu: z FFT signálu} \quad (4.11)$$

4.4 Neuronová síť

Prvním vybraným modelem ke klasifikaci byla jednovrstvá neuronová síť se zpětným šířením chyby, vytvořena pomocí Matlab balíčku Deep Learning (schéma na Obr. 4.4). Počet neuronů skryté vrstvy (Hidden) byl nastaven na 10, s trénovací funkcí jenž přepočítává váhy dle Levenberg-Marquardt optimalizace (v Matlabu jako *trainlm*). Jako aktivační funkce skryté vrstvy byla zvolena logistická sigmoida. Výstupní vrstvu (Output) tvoří 6 neuronů (podle 6 klasifikovaných aktivit) hyperbolický tangens. Na vstup sítě (Input) byly přivedeny matice příznaků, zvlášť pro každý dataset. Zvolenou kritériální funkcí pro trénování byla střední kvadratická odchylka (MSE). Dalšími z upravovaných parametrů byly krok učení, maximální přípustná odchylka, počet epoch a poměry rozdělení dat na trénovací, validační a testovací (poměr ve stejném pořadí 0,5:0,25:0,25). Každý z těchto parametrů byl v rámci optimalizace upravován podle výsledné úspěšnosti klasifikace sítě. Konečné hodnoty parametrů sítě spolu s dosaženými jsou vypsány v následující kapitole.



Obr. 4.4: Schéma vlastní neuronové sítě

Po naučení sítě byla úspěšnost klasifikace pro testovací sadu dat určena pomocí matice záměn (neboli confusion matrix) (Obr. 5.1), která se běžně používá pro vyhodnocení klasifikačních úloh algoritmů strojového učení. Matice obsahuje ve sloupcích skutečné hodnoty klasifikovaných kategorií a v řádcích výstupy použitého klasifikátoru. Celková úspěšnost klasifikace je reprezentována jako poměr součtu správně rozlišených (TP, TN) detekovaných kategorií ke součtu falešně pozitivních (FP) a falešně negativních (FN). V matici záměn se tato hodnota nachází v pravém dolním rohu.

$$\text{Výpočet úspěšnosti (přenosti klasifikace)} : \frac{TP + TN}{TP + TN + FP + FN} \quad (4.12)$$

5 Optimalizace algoritmu

V prvním kroku klasifikace pomocí sítě byly použity pro trénování a testování všechny datasety zvlášť. K průběžnému hodnocení úspěšnosti klasifikace byla použita matice záměn vypočtená z výstupních hodnot sítě a očekávaných výstupů dle matice cílů (Obr. 5.1). Matice příznaků a cílů byly zamíchány, aby bylo pořadí aktivit v nich nepravidelné, což by mělo napomoci k lepší generalizaci sítě. Na všech datech byl odzkoušen krok normalizace hodnot příznaků do intervalu $[-1,1]$, což dá všem příznakům stejnou váhu a střední hodnotu rovnu nule. Tento krok se však ukázal jako neuspokojivý, protože měl za následek nižší celkovou úspěšnost klasifikace u všech datasetů. Krok normalizace byl odzkoušen na síti před i po optimalizaci (výsledky jsou shrnuty v následující kapitole).

Po vyhodnocení výsledků učení a úspěšnosti neoptimalizované sítě, byly pozměněny parametry počtu epoch na 100, kroku učení na 0,1 a minimální přípustné chyby na 0,01. Po těchto úpravách dosahuje síť lepších výsledků klasifikace na všech datasetech.

Matice záměn pro dataset WARD bez normalizace

Klasifikované aktivity	Chůze	57 15.2%	17 4.5%	2 0.5%	0 0.0%	0 0.0%	1 0.3%	74.0% 26.0%
	Do schodů	2 0.5%	42 11.2%	6 1.6%	0 0.0%	0 0.0%	1 0.3%	82.4% 17.6%
	Ze schodů	0 0.0%	7 1.9%	46 12.3%	0 0.0%	1 0.3%	0 0.0%	85.2% 14.8%
	Sed	0 0.0%	0 0.0%	1 0.3%	46 12.3%	1 0.3%	1 0.3%	93.9% 6.1%
	Stání	0 0.0%	0 0.0%	0 0.0%	18 4.8%	58 15.5%	0 0.0%	76.3% 23.7%
	Leh	0 0.0%	1 0.3%	0 0.0%	0 0.0%	0 0.0%	67 17.9%	98.5% 1.5%
		96.6% 3.4%	62.7% 37.3%	83.6% 16.4%	71.9% 28.1%	96.7% 3.3%	95.7% 4.3%	84.3% 15.7%
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	
		Cílové aktivity						

Obr. 5.1: Příklad matice záměn z testování datsetu WARD

6 Výsledky a diskuze

V této kapitole jsou shrnuty dosažené výsledky testování všech tří datasetů. Jak již bylo zmíněno v předchozí kapitole, při klasifikaci pomocí sítě bylo nejprve vyzkoušeno použití normalizace hodnot do intervalu $[-1,1]$, což nevedlo ke zlepšení výsledků (jak patrné v Tab. 6.1). Pro kratší datasety vlastních dat a WARD se výsledky bez normalizace pohybují okolo 84-88%, což je méně než u datasetu UCI HAR z důvodu většího rozsahu dat (sít se lépe naučí).

Dataset	Vlastní	WARD	UCI HAR
Úspěšnost bez normalizace	88,1%	84,3%	92,2%
Úspěšnost s normalizací	74,8%	74,9%	91,9%

Tab. 6.1: Dosažené hodnoty úspěšnosti klasifikace sítě před optimalizací

Matice záměn pro vlastní data po optimalizaci sítě								
Klasifikované aktivity	Chůze	<div><div>36</div><div>17.1%</div></div>	<div><div>1</div><div>0.5%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>1</div><div>0.5%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>94.7%</div><div>5.3%</div></div>
	Do schodů	<div><div>1</div><div>0.5%</div></div>	<div><div>36</div><div>17.1%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>97.3%</div><div>2.7%</div></div>
	Ze schodů	<div><div>0</div><div>0.0%</div></div>	<div><div>5</div><div>2.4%</div></div>	<div><div>32</div><div>15.2%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>86.5%</div><div>13.5%</div></div>
	Sed	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>26</div><div>12.4%</div></div>	<div><div>1</div><div>0.5%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>96.3%</div><div>3.7%</div></div>
	Stání	<div><div>0</div><div>0.0%</div></div>	<div><div>1</div><div>0.5%</div></div>	<div><div>2</div><div>1.0%</div></div>	<div><div>1</div><div>0.5%</div></div>	<div><div>31</div><div>14.8%</div></div>	<div><div>1</div><div>0.5%</div></div>	<div><div>86.1%</div><div>13.9%</div></div>
	Leh	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>0</div><div>0.0%</div></div>	<div><div>35</div><div>16.7%</div></div>	<div><div>100%</div><div>0.0%</div></div>
		<div><div>97.3%</div><div>2.7%</div></div>	<div><div>83.7%</div><div>16.3%</div></div>	<div><div>94.1%</div><div>5.9%</div></div>	<div><div>96.3%</div><div>3.7%</div></div>	<div><div>93.9%</div><div>6.1%</div></div>	<div><div>97.2%</div><div>2.8%</div></div>	<div><div>93.3%</div><div>6.7%</div></div>
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	
		Cílové aktivity						

Obr. 6.1: Matice záměn z testování vlastního datasetu

Z výsledné matice (Obr. 6.1) vyplývá, že síť nejvíce chybovala ve vyhodnocení aktivity chůze ze schodů, kterou v 5 případech vyhodnotila jako chůzi do schodů, což je pochopitelné vzhledem k velmi podobnému rozložení tíhového zrychlení do jednotlivých os (x, y a z). I když zde síť dosáhla nejvyšší úspěšnosti, nebude mít relevantní schopnost reagovat na jiná data, z důvodu nižšího rozsahu trénovací množiny dat.

Matice záměn pro dataset WARD po optimalizaci sítě

Klasifikované aktivity	Chůze	53 14.1%	8 2.1%	0 0.0%	1 0.3%	0 0.0%	0 0.0%	85.5% 14.5%
	Do schodů	5 1.3%	49 13.1%	6 1.6%	1 0.3%	0 0.0%	0 0.0%	80.3% 19.7%
	Ze schodů	0 0.0%	8 2.1%	57 15.2%	0 0.0%	0 0.0%	0 0.0%	87.7% 12.3%
	Sed	0 0.0%	1 0.3%	0 0.0%	47 12.5%	5 1.3%	2 0.5%	85.5% 14.5%
	Stání	0 0.0%	2 0.5%	1 0.3%	11 2.9%	60 16.0%	0 0.0%	81.1% 18.9%
	Leh	0 0.0%	2 0.5%	0 0.0%	0 0.0%	0 0.0%	56 14.9%	96.6% 3.4%
		91.4% 8.6%	70.0% 30.0%	89.1% 10.9%	78.3% 21.7%	92.3% 7.7%	96.6% 3.4%	85.9% 14.1%
		Cílové aktivity						
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	

Obr. 6.2: Matice záměn z testování datasetu WARD

Výsledky z databáze WARD měly celkovou úspěšnost testování nejnižší. Opět se zde objevuje chyba v určení aktivity sed, která byla v 11 případech zaměněna se stáním a navíc se zde projevují chyby v klasifikaci jednotlivých typů chůze (levý horní roh matice na Obr. 6.2).

Matice záměn pro dataset UCI HAR po optimalizaci sítě								
Klasifikované aktivity	Chůze	403 15.7%	17 0.7%	12 0.5%	1 0.0%	0 0.0%	0 0.0%	93.1% 6.9%
	Do schodů	21 0.8%	379 14.7%	9 0.3%	0 0.0%	0 0.0%	0 0.0%	92.7% 7.3%
	Ze schodů	7 0.3%	7 0.3%	339 13.2%	0 0.0%	0 0.0%	0 0.0%	96.0% 4.0%
	Sed	0 0.0%	0 0.0%	0 0.0%	385 15.0%	53 2.1%	0 0.0%	87.9% 12.1%
	Stání	0 0.0%	0 0.0%	0 0.0%	49 1.9%	411 16.0%	0 0.0%	89.3% 10.7%
	Leh	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	482 18.7%	100% 0.0%
		93.5% 6.5%	94.0% 6.0%	94.2% 5.8%	88.5% 11.5%	88.6% 11.4%	100% 0.0%	93.2% 6.8%
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	
Cílové aktivity								

Obr. 6.3: Matice záměn z testování datasetu UCI HAR

Klasifikace ze samostatného datasetu UCI HAR dosahovala, s ohledem na jeho velikost, velmi uspokojivých výsledků (Obr. 6.3). Chyby, jenž se vyskytují již byly popsány v předchozích dvou odstavcích, opět je zde nejlépe vyhodnocenou aktivitou leh na zádech, při které je odlišné rozložení tíhové zrychlení v ose protínající tělo nositele akcelerometru (závisí na zařízení, znázorněno v Tab 2.1, 2.2 a 4.1).

Pro trénování sítě bylo z každého datasetu vyčleněno 50%, validaci 25% a pro testování zbylých 25%. Nevýhodou použité neuronové sítě je, že má tendence vyhodnocovat aktivity s rozdílnou úspěšností při každém učení. Byly odzkoušeny i jiné trénovací funkce, jako gradientní sestup se zpětným šířením chyby. Výsledky klasifikace sice byly stabilnější, ale celkově méně přesné.

Po optimalizaci upravením jednotlivých parametrů, jak již bylo zmíněno na konci předchozí kapitoly, dosahuje síť poměrně slušných výsledků úspěšnosti klasifikace (Tab. 6.2). Podle matice záměn nejlépe vyhodnotila vlastní naměřená data s celkovou úspěšností 93,3%.

Dataset	Vlastní	WARD	UCI HAR
Úspěšnost po optimalizaci sítě	93,3%	85,9%	93,2%

Tab. 6.2: Dosažené hodnoty úspěšnosti klasifikace sítě po optimalizaci

Původním záměrem použitých databází bylo využít jejich obsah k naučení neuronové sítě a následně ji použít ke klasifikaci vlastních dat. Ukázalo se však, že provedení tohoto postupu naráží na jisté problémy způsobené odlišnou povahou dat v závislosti na použitém senzoru k měření dat. V Tab. 6.3 jsou shrnuty výsledky testování mezi jednotlivými datasety.

Trénovací dataset	Vlastní		WARD		UCI	
Testovací dataset	WARD	UCI	Vlastní	UCI	Vlastní	WARD
Úspěšnost klasifikace	16,9%	20,9%	35,8%	17,3%	19,0%	15,9%

Tab. 6.3: Dosažené hodnoty úspěšnosti klasifikace

6.1 Porovnání výsledků neuronové sítě s SVM

Úspěšnost klasifikace neuronové sítě byla porovnána s modelem SVM naučeným skrze aplikaci Classification Learner, která je také součástí balíčku Deep Learning. Model byl naučen na 75% dat z každého datasetu a testován na zbylých 25%. Jako ochrana proti přeučení modelu (overfitting) byla v aplikaci Classification Learner ponechána výchozí volba křížové validace se základním nastavením. Z výsledné hodnoty jsou nižší v porovnání s neuronovou sítí, zejména u vlastních naměřených dat, kde byla úspěšnost při testování pouze 19,5%.

Dataset	Vlastní	WARD	UCI HAR
Úspěšnost klasifikace	19,5%	89,1%	84,3%

Tab. 6.4: Dosažené hodnoty úspěšnosti klasifikace pomocí SVM

Matice záměn SVM pro vlastní data								
Klasifikované aktivity	Chůze	4 1.9%	5 2.4%	6 2.9%	4 1.9%	4 1.9%	5 2.4%	14.3% 85.7%
	Do schodů	3 1.4%	9 4.3%	9 4.3%	8 3.8%	9 4.3%	3 1.4%	22.0% 78.0%
	Ze schodů	7 3.3%	4 1.9%	6 2.9%	6 2.9%	6 2.9%	5 2.4%	17.6% 82.4%
	Sed	5 2.4%	5 2.4%	7 3.3%	5 2.4%	8 3.8%	4 1.9%	14.7% 85.3%
	Stání	6 2.9%	6 2.9%	7 3.3%	5 2.4%	10 4.8%	5 2.4%	25.6% 74.4%
	Leh	2 1.0%	8 3.8%	5 2.4%	5 2.4%	7 3.3%	7 3.3%	20.6% 79.4%
		14.8% 85.2%	24.3% 75.7%	15.0% 85.0%	15.2% 84.8%	22.7% 77.3%	24.1% 75.9%	19.5% 80.5%
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	
		Cílové aktivity						

Obr. 6.4: Matice záměn z testování vlastních dat pomocí SVM

Matice záměn SVM pro data set WARD								
Klasifikované aktivity	Chůze	61 16.3%	3 0.8%	1 0.3%	0 0.0%	0 0.0%	0 0.0%	93.8% 6.2%
	Do schodů	8 2.1%	56 14.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	87.5% 12.5%
	Ze schodů	1 0.3%	3 0.8%	52 13.9%	0 0.0%	0 0.0%	0 0.0%	92.9% 7.1%
	Sed	0 0.0%	0 0.0%	0 0.0%	49 13.1%	20 5.3%	1 0.3%	70.0% 30.0%
	Stání	0 0.0%	0 0.0%	0 0.0%	1 0.3%	58 15.5%	0 0.0%	98.3% 1.7%
	Leh	0 0.0%	0 0.0%	0 0.0%	2 0.5%	1 0.3%	58 15.5%	95.1% 4.9%
		87.1% 12.9%	90.3% 9.7%	98.1% 1.9%	94.2% 5.8%	73.4% 26.6%	98.3% 1.7%	89.1% 10.9%
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	
		Cílové aktivity						


Obr. 6.5: Matice záměn z testování WARD pomocí SVM

Matice záměn SVM pro data set UCI HAR								
Klasifikované aktivity	Chůze	381 14.8%	25 1.0%	31 1.2%	0 0.0%	0 0.0%	0 0.0%	87.2% 12.8%
	Do schodů	101 3.9%	302 11.7%	20 0.8%	0 0.0%	0 0.0%	0 0.0%	71.4% 28.6%
	Ze schodů	37 1.4%	47 1.8%	289 11.2%	0 0.0%	0 0.0%	0 0.0%	77.5% 22.5%
	Sed	1 0.0%	1 0.0%	0 0.0%	356 13.8%	63 2.4%	0 0.0%	84.6% 15.4%
	Stání	0 0.0%	0 0.0%	0 0.0%	76 3.0%	374 14.5%	0 0.0%	83.1% 16.9%
	Leh	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	470 18.3%	99.8% 0.2%
		73.3% 26.7%	80.5% 19.5%	85.0% 15.0%	82.4% 17.6%	85.4% 14.6%	100% 0.0%	84.3% 15.7%
		Cílové aktivity						
		Chůze	Do schodů	Ze schodů	Sed	Stání	Leh	

Obr. 6.6: Matice záměn z testování UCI HAR pomocí SVM

Výsledné matice záměn (Obr. 6.4, 6.5, 6.6) jsou z testování zbylých 25% dat naučenými modely (naučeny na 75% z datasetu) SVM pro každý dataset zvlášť. V rámci testování byla prozkoumána i možnost učit model na databázích a použít takto naučený model ke klasifikaci vlastních naměřených dat, avšak podobně jako u neuronových byly výsledky více než neuspokojivé. Některé aktivity ani nebyly zaregistrovány a většina naměřených dat byla klasifikátorem SVM označena jako jedna aktivita.

Na bodovém diagramu (Obr. 6.7) vytvořeném lze vidět nízkou separabilitu dat dle dvou zvolených příznaků, která v kombinaci s nízkým rozsahem dat oproti UCI HAR a WARD nestačí pro kvalitní naučení SVM. Z diagramu je patrné, že vybrané příznaky nedostatečně separují daný dataset, což má za následek neschopnost rozeznávat druhy jednotlivých aktivit. V ideálním případě bychom chtěli na bodovém diagramu vidět snadno oddělitelné shluky odděleny barevně dle jednotlivých aktivit.



Obr. 6.7: Bodový diagram pro znázornění nízké separability

Fusion Method	SVM	k-NN
Feature-level fusion	97.12%	91.75%
Score-level fusion	96.44%	84.02%

Obr. 6.8: Výsledná úspěšnost klasifikace, převzato z:[12]

K dosažení lepších výsledků by jistě pomohla pokročilejší metoda extrakce příznaků, tak jako ji navrhuji autoři článku v časopisu IEEE SENSORS JOURNAL[12]. Jejich práce se zabývala klasifikací aktivit z datasetu UCI HAR, který byl použit i v této práci. Vybrané příznaky byly rozděleny do dvou kategorií, které byly následně podrobeny fúzi příznaků dle jejich skóre a úrovně. Jako klasifikátor bylo zvoleno SVM a algoritmu k-nejbližších sousedů (k-NN) s nejvyšší výslednou přesností klasifikace 97,12%[12](Obr. 6.8).

Závěr

Prvním úkolem bakalářské práce bylo provést rešerši v oblasti snímání dat denních aktivit pomocí akcelerometrů, která byla shrnuta v první kapitole této práce. Bylo v ní popsáno praktické využití nasnímaných dat a technologie, která se při jejich měření používá. V rámci popisu fungování akcelerometrů bylo představeno a popsáno monitorovací zařízení FAROS 180, které bylo používáno k nasnímání vlastních dat. Ke klasifikaci bylo vybráno 6 aktivit zahrnujících chůzi, chůzi do schodů, ze schodů, stání, sed a leh. Aktivita byly zvoleny dle vybraných veřejně přístupných databází.

Ve 2. kapitole byly popsány vybrané databáze WARD a UCI HAR, spolu se základním popisem formátu jejich dat a metodiky snímání. Databáze se od sebe liší v použitém zařízení k měření aktivit, počtem pacientů a celkovou délkou záznamu. Autoři UCI HAR se rozhodli použít konvenční zařízení v podobě mobilního telefonu, oproti vlastnímu technickému řešení autorů databáze WARD. Ti se rozhodli navrhnout a zkonstruovat vlastní síť senzorů, jenž je schopna samostatně optimalizace měření a odesílat naměřená data na server, který používá jako své uložení.

V poslední kapitole teoretické části byla shrnuta teorie týkající se klasifikace aktivit. Následně byl popsán princip algoritmů SVM a neuronové sítě, pomocí kterých byla realizována klasifikace vybraných aktivit z dat. U neuronových sítí byla stručně pospána jejich historie a postupný vývoj až do současnosti. Základní princip fungování byl popsán na modelu perceptronu spolu se související rovnicí. Dále bylo vysvětleno jakým způsobem probíhá úprava vah v síti a druhy metod učení. Následně byl vysvětlen pojem příznak, jeho souvislost s extrakcí dat ze signálů a popsána jedna z metod příznakové analýzy.

V praktické části byla nejprve představena data naměřená záznamníkem FAROS 180 a výčet jednotlivých aktivit. Následuje popis metodiky snímání a porovnání s daty z databází UCI HAR a WARD. Dále byl popsán průběh přípravy a zpracování dat jak z databází, tak z vlastního měření. V poslední části 4. kapitoly následuje popis vlastní neuronové sítě spolu s vysvětlením metodiky vyhodnocování úspěšnosti klasifikace skrze matici záměn.

Dalším úkolem bylo vhodně optimalizovat vlastní algoritmus používaný ke klasifikaci. U neuronové sítě se tento krok týkal nastavení jednotlivých paramterů, kterými byly počet epoch, krok učení, přípustná chyba a nastavení aktivačních funkcí skryté a výstupní vrstvy. Dále byla vyzkoušena normalizace příznakové matice do intervalu $[-1,1]$ která, jako bylo zjištěno, vedla spíše ke zhoršení úspěšnosti.

Dosažené výsledky klasifikace jsou shrnuty a prodiskutovány v poslední kapitole. Učení sítě probíhalo na 50% celkového rozsahu pro každý dataset zvlášť. S následným testováním na 25% celkového rozsahu dat (zbylých 25% bylo použito při validaci učení) Před optimalizací dosahovala síť maximální úspěšnosti 88,1% pro

vlastní naměřená data, 84,3% pro data z WARD a 92,2% pro data z UCI HAR. Po optimalizaci dosahovala síť maximální úspěšnosti 93,3% pro vlastní naměřená data, 85,9% pro data z WARD a 93,2% pro data z UCI HAR. Byla prověřena i možnost učení sítě na jednom datasetu a testování na jiném (například učení na vlastních datech a testování na WARD). Na základě výsledků z tohoto testování bylo zjištěno, že neuronová síť dynamicky nereaguje na odlišný dataset. V poslední části diskuze byly porovnány výsledky klasifikace mezi neuronovou sítí a SVM. Model SVM byl trénován na 75% a testován na 25% celkového rozsahu, pro každý dataset zvlášť. Výsledky úspěšnosti klasifikace byly nižší než u neuronových sítí a to zejména při klasifikování vlastních naměřených dat. Možné důvody z jakých příčin se tak stalo jsou popsány pomocí bodového diagramu, na kterém lze vidět nízkou separabilitu dat, dle vybraných příznaků. Na konci diskuze byly popsány dosažené výsledky jiných autorů, kteří používali jako zdroj dat databázi UCI HAR.

Literatura

- [1] ANG, Fan a Lianyi ZHANG. *Real-time human activity classification by accelerometer embedded wearable devices. 2017 4th International Conference on Systems and Informatics (ICSAI)* [online]. IEEE, 2017, 2017, 2017, 469-473 [cit. 2021-5-28]. ISBN 978-1-5386-1107-4. Dostupné z: doi:10.1109/ICSAI.2017.8248338
- [2] Allen Yang, Roozbeh Jarafi, Shankar Sastry, and Ruzena Bajcsy, *Distributed Recognition of Human Actions Using Wearable Motion Sensor Networks* [online]. JAISE 2009 [cit. 2020-11-27]. Dostupné z: <<https://people.eecs.berkeley.edu/~yang/paper/JAISE08-AllenYang.pdf>>
- [3] Katie McEntire. *Best Safety Wearables for Seniors* [online]. 2020 [cit. 2021-01-02] Dostupné z: <<https://www.safewise.com/blog/top-safety-wearable-products-for-seniors/>>
- [4] ALI, N. M. a GJ TING. *Issues and Challenges of Sensor Technologies in Microelectromechanical System (MEMS) in Smartphones for Motion Tracking Applications. Journal of Telecommunication, Electronic and Computer Engineering* [online]. 2018, 2018(10), 135-140 [cit. 2020-11-25]. ISSN 2289-8131. Dostupné z: <<https://www.semanticscholar.org/paper/Issues-and-Challenges-of-Sensor-Technologies-in-in-Ali-Ting/1de64b2f5b1a95660ff91efb73562fc5fa530ad1?p2df>>
- [5] *The History of the Accelerometer* <<https://qringtech.com/TryMe/wp-content/uploads/2014/01/HistoryOfTheAccelerometer.pdf>>
- [6] MathWorks, *Accelerometer* [online]. [cit. 2021-01-02] Dostupné z: <https://www.mathworks.com/help/supportpkg/android/ref/simulinkandroidsupportpackage_galaxys4_accelerometer.png>
- [7] Bittium Faros 180TM Solution Pack [online]. [cit. 2021-04-02] Dostupné z: <<https://shop.bittium.com/product/36/bittium-faros-180-solution-pack>>
- [8] Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra and Jorge L. Reyes-Ortiz. *A Public Domain Dataset for Human Activity Recognition Using Smartphones. 21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning* [online]. ESANN 2013 [cit. 2020-12-17]. Dostupné z: <<https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones>>

- [9] *Support Vector Machines(SVM) — An Overview. Towardsdatascience* [online]. Kanada: towardsdatascience, 2018, June 16 2018 [cit. 2021-5-14]. Dostupné z: <https://towardsdatascience.com/https-medium-com-pupalerushikesh-svm-f4b42800e989>
- [10] *Allen Yang, Roozbeh Jarafi, Shankar Sastry, and Ruzena Bajcsy, Distributed Human Action Recognition via Wearable Motion Sensor Networks* [online]. Dostupné z: <<https://people.eecs.berkeley.edu/~yang/paper/JAISE08-AllenYang.pdf>>
- [11] *Jiří Kozumplík, Ivo Provazník. Umělá inteligence v medicíně* Brno 2007
- [12] *JAIN, Ankita a Vivek KANHANGAD. Human Activity Classification in Smartphones Using Accelerometer and Gyroscope Sensors. IEEE Sensors Journal* [online]. 2018, 18(3), 1169-1177 [cit. 2021-5-28]. ISSN 1530-437X. Dostupné z: doi:10.1109/JSEN.2017.2782492

Seznam symbolů, veličin a zkratek

GPS	Global Positioning System
IZS	Integrovaný záchranný systém
g	tíhové zrychlení
mV	jednotka veličiny napětí Hz! (Hz!) jednotka veličiny frekvence
MEMS	Micro Electro Mechanical Systems
IMU	Intertia Measurement Unit
UCI HAR	University of California, Irvine Human Activity Recognition
WARD	Wearable Action Recognition Database
PCA	Principle Component Analysis neboli analýza hlavních komponent
SVM	Support Vector Machine neboli algoritmus podpůrných vektorů
STD	směrodatná odchylka
RMS	Root Mean Square neboli efektivní hodnota
SMA	Signal Magnitude Area
FFT	Fast Fourier Transform neboli rychlá Fourierova transformace
MSE	Mean Squared Error neboli středná kvadratická odchylka